

基于支持向量数据描述的印刷图像套准状态检测方法

简川霞, 敖银辉, 郭本果, 范彬祥

(广东工业大学, 广州 510006)

摘要: **目的** 针对不均衡的印刷标志图像训练集构建的二分类模型, 对少类的印刷套不准图像识别准确率低的问题, 研究不均衡印刷标志图像套准状态的单分类模型识别方法。**方法** 提出支持向量数据描述方法, 实现多类的印刷套准图像和少类的印刷套不准图像的准确识别。采用多类的印刷套准图像训练支持向量数据描述, 构建模型。采用网格寻优方法和交叉验证方法确定模型的最佳参数 C 和 σ 。利用模型对印刷标志图像套准状态进行识别。**结果** 采用文中提出的支持向量数据描述方法, 对印刷标志图像套准状态识别获得的总体识别率 a 为 0.9500, 印刷套准图像和印刷套不准图像识别准确率的几何平均数 G_{mean} 为 0.9513。**结论** 文中提出的方法获得的总体识别率 a 和识别率的几何平均数 G_{mean} 要优于实验中的其他方法。

关键词: 支持向量数据描述; 印刷套准; 不均衡数据

中图分类号: TS807 文献标识码: A 文章编号: 1001-3563(2019)11-0212-06

DOI: 10.19554/j.cnki.1001-3563.2019.11.032

Registration Recognition Methods of Printing Images Based on Support Vector Data Description

JIAN Chuan-xia, AO Yin-hui, GUO Ben-guo, FAN Bin-xiang

(Guangdong University of Technology, Guangzhou 510006, China)

ABSTRACT: The paper aims to research a single classification model recognition method for imbalanced printing mark images in registration state to solve the problem that the binary classifier model constructed from the imbalanced training set of printing mark images cannot recognize the minority printing misregistration images accurately. The support vector data description (SVDD) method was proposed to recognize the majority registration images and the minority misregistration images accurately. The majority printing registration images were used for training of SVDD, and the SVDD model was constructed. The grid optimization method and cross validation method were used to determine the optimal parameters C and σ of the model. The registration of the printing mark images was identified with the model. The proposed SVDD method achieved 0.9500 of overall recognition accuracy a , and 0.9513 of geometric mean of the recognition accuracy G_{mean} . The overall recognition accuracy a and the geometric mean of the recognition accuracy G_{mean} obtained by the proposed method are superior to that of other methods in the experiment.

KEY WORDS: support vector data description; printing registration; imbalanced data

收稿日期: 2019-02-16

基金项目: 广东工业大学青年基金重点项目 (17QNZD001); 广东省信息物理融合系统重点实验室项目 (2016B030301008); 广东工业大学大学生创新创业项目 (xj201811845001)

作者简介: 简川霞 (1979—), 男, 博士, 广东工业大学讲师, 主要研究方向为机器视觉与图像处理。

印刷套准是多色印刷工艺中一个重要环节。目前,印刷套准的检测主要依赖人工抽检完成,严重影响其工作效率,因此,基于机器视觉的印刷套准状态检测方法被学者们广泛关注^[1-5]。于丽杰提取了印刷标志图像的颜色特征和纹理特征,并设计了最小距离分类器识别套准状态。简川霞提取了印刷标志图像的灰度共生矩阵来描述图像的纹理特征,并采用 Adaboost 分类器实现印刷套准状态的识别。这些方法存在对印刷套不准图像识别准确率低的局限性。在实际生产中,获取的印刷套准图像数量远多于印刷套不准图像,因此由这两类图像组成的训练集是不均衡的,这导致了由不均衡训练集学习获得的印刷套准状态检测二分类模型,对印刷套不准图像的识别准确率低的问题。鉴于此,文献^[6]从训练集的角度出发,提出新的集成采样方法对不均衡的训练集进行预处理,以实现训练集的相对均衡,提高由此建立的二分类模型对印刷套不准图像的识别准确率。如果原训练集中存在一些噪声数据,训练集的预处理效果会大大降低,影响二分类模型对印刷标志图像套准状态分类性能的提高。同时,训练集的预处理增加了二分类模型的学习时间。支持向量数据描述 (Support vector data description, SVDD) 是一种单分类模型,在训练时只对一类数据进行训练,建立相应模型。在分类时,该模型能够判断测试数据是否属于目标类,因此 SVDD 模型非常适合样本数据分布不均衡的情况。SVDD 已经被广泛应用于机器故障诊断^[7-8]、产品缺陷检测^[9-11]和图像分类^[12-13]等方面。

文中从分类模型角度出发,采用单分类模型(即支持向量数据描述分类模型),对仅包含单类样本的训练集进行学习,以避免二分类模型受不均衡训练集的影响。任意两色之间的套准是四色套准的基础,因此仅研究两色之间的套准状态检测,文中提出的方法也适用于四色之间的套准状态检测。

1 印刷图像套准状态检测流程

使用的印刷标志灰度图像见图 1,提出的印刷标志图像套准状态检测流程见图 2。用于 SVDD 模型的训练集仅包含数量较多的印刷套准图像,即训练集中只有一类图像。首先提取印刷套准图像的多个纹理特征(提取了图像灰度共生矩阵的 8 维纹理特征)数据,用于单类分类模型 SVDD 的学习训练,建立 SVDD 印刷套准识别模型。模型中的参数 C 和 σ 采用五折交叉验证法和网格寻优算法确定。然后对待测的印刷标志图像进行纹理特征提取,将提取的特征数据输入 SVDD 模型中进行分类。如果待测图像的特征数据点在超球体内部(含表面上),那么其对应的图像为印刷套准图像,否则为印刷套不准图像。




图 1 印刷标志
Fig.1 Printingmark




图 2 印刷标志图像套准状态检测流程
Fig.2 Printing mark image registration detection flowchart

2 支持向量数据描述

Tax 和 Duin 在 2004 年提出了支持向量数据描述 (SVDD) 算法^[14],其算法思想是:将原空间的样本点(包括正常样本点和异常点)通过映射函数映射到高维特征空间中,在此高维空间中试图找到一个尽可能小的超球体,覆盖尽可能多的正常样本点数据,而异常样本点排除在超球体外。SVDD 的超球体描述示意图图 3,目标样本位于超超球体内部,支持向量样本位于超球体的表面,非目标样本位于超球体的外部。支持向量假定训练集 $x_i \in R^n, i=1,2 \dots l$, SVDD 数学模型为:

$$\begin{aligned} \min_{R, \alpha, \xi} \quad & R^2 + C \sum_{i=1}^l \xi_i \\ \text{s.t.} \quad & \|\phi(x_i) - \alpha\|^2 \leq R^2 + \xi_i, i=1 \dots l \\ & \xi_i \geq 0, i=1 \dots l \end{aligned} \quad (1)$$

式中: ϕ 是将数据从低维空间映射入高维空间的映射函数; l 是样本点数量; ξ_i 是宽松因子; R 和 α 分别为高维特征空间中超球体的半径和球心。如果该数据点在超球体内部或者表面的时候 $\xi_i=0$, 其中落在超球体表面的数据点(也是正常样本点),称为支持向量。其中 $C > 0$, 是惩罚常数,平衡超球体的体积和错分样本比例。如果 C 取值较大,意味着寻找一

个较大的超球体覆盖尽量多的数据点；如果 C 比较小，即寻找一个较小的超球体包含尽量多的数据点。如果测试数据 x 满足式 (2)，则为野值点。

$$\|\phi(x) - \alpha\|^2 > R^2 \quad (2)$$

该模型的对偶问题如下：

$$\begin{aligned} \max_{\alpha} \quad & \sum_{i=1}^l \alpha_i \kappa(x_i, x_j) - \alpha^T \kappa \alpha \\ \text{s.t.} \quad & \mathbf{e}^T \alpha = 1, \\ & 0 \leq \alpha_i \leq C, i = 1, 2 \dots l \end{aligned} \quad (3)$$

式中： $\mathbf{e} = [1 \dots 1]^T$ ； $\alpha = [\alpha_1 \dots \alpha_l]^T$ ； κ 为核函数， $\kappa(x_i, x_j) = \phi(x_i)^T \phi(x_j)$ ， $\forall 1 \leq i, j \leq l$ 。

该对偶问题的求解类似于支持向量机模型的对偶问题求解方法。根据拉格朗日乘子法，模型的对偶优化问题：

$$\begin{aligned} \max \quad & \sum_{i=1}^l \beta_i \kappa(x_i, x_j) - \sum_{i=1}^l \sum_{j=1}^l \beta_i \beta_j \kappa(x_i, x_j) \\ \text{s.t.} \quad & \sum_{i=1}^l \beta_i = 1, \beta_i \in [0, C], i = 1 \dots l \end{aligned} \quad (4)$$

这里 β_i 是拉格朗日乘子。求解对偶优化问题，得超球体球心为：

$$\alpha = \sum_{i=1}^l \beta_i \phi(x_i) \quad (5)$$

超球体半径为：

$$R = \kappa(x, x) - 2 \sum_{i=1}^l \beta_i \kappa(x_i, x) + \sum_{i=1}^l \sum_{j=1}^l \beta_i \beta_j \kappa(x_i, x_j) \quad (6)$$

对于测试样本点 x ，如果满足 $\|\phi(x) - \alpha\|^2 - R^2 \leq 0$ ，则其为目标样本点；否则，其为非目标样本点。常用的核函数主要有：线性核函数、高斯

*目标样本 · 支持向量 +非目标样本




图 3 SVDD 超球体描述示意

Fig.3 Schematic diagram of SVDD hypersphere description

(Gaussian) 核函数 (又称径向基核函数, RBF)、多项式核函数和 Sigmoidal 核函数。核函数的选择影响着 SVDD 模型的泛化能力。研究表明, 当缺少先验知识时, 选择高斯核函数比选择其他核函数分类效果要好^[15]。高斯核函数的形式为：

$$\kappa(x_i, x_j) = \exp\left(-\frac{\|x_i - x_j\|^2}{2\sigma^2}\right), \sigma > 0 \quad (7)$$

式中： σ 为核宽度，间接描述了 SVDD 高维的空间特性。

3 模型参数优化

SVDD 模型采用高斯核函数，模型中的惩罚参数 C 和高斯核函数中的核宽度 σ 影响着 SVDD 分类器的性能^[16]。采用 k 折交叉验证法和网格寻优法来选择最优的 C 和 σ 。 k 折交叉验证法^[17]是将训练样本随机分成 k 个互不相交、大小相同的子集，任取 $k-1$ 个子集作为训练集，剩下的一个子集作为测试集，循环 k 次之后求预测准确率的平均值。所有的样本都参与了训练集和测试集，每个样本都被验证一次。常用 10 折和 5 折交叉验证法，5 折交叉验证法见图 4。

网格寻优法是穷举法^[18]，穷举各个模型参数 (C, σ) 组合，找出分类性能最佳的 (C, σ) 。其参数确定方法如下：选定一组 (C, σ) ，如 $C \in [2^{-10}, 2^{15}]$ ，搜索步长 $d_C = 1$ ， $\sigma \in [2^{-15}, 2^{10}]$ ，搜索步长 $d_\sigma = 1$ 。在 (C, σ) 构成的二维网格中，对应每一个节点 (C, σ) 值，按照交叉验证方法计算出平均的预测准确率。根据每一个节点 (C, σ) 对应的平均预测准确率，绘制等高线。根据等高线图，确定最佳的 (C, σ) 值。网格寻优法是同时搜索多个相互独立的参数对，易于并行搜索；且参数较少时，搜索的时间也较少。

文中采用网格寻优法尝试各种可能的 (C, σ) 值，进行 k 折交叉验证，找出使交叉验证平均预测准确率最高的 (C, σ) 值，作为最终的模型参数。文中 k 取 5，即 5 折交叉验证。




图 4 5 折交叉验证法

Fig.4 Five-fold cross validation

4 实验

4.1 印刷图像套准识别评价指标

采用总体分类准确率 a 和分类准确率几何平均数 G_{mean} ^[19]来评价单分类模型 SVDD 的分类性能。 a 反映了 SVDD 对印刷标志图像套准状态的总体识别能力； G_{mean} 反映了 SVDD 对印刷套准图像和印刷套不准图像识别能力的总体考虑。为了计算 a 和 G_{mean} ，引入混合矩阵（见表 1）加以说明。

$$G_{\text{mean}} = \sqrt{a^+ \times a^-}$$
 (8)

$$a = \frac{T_p + T_N}{(T_p + F_N + F_p + T_N)}$$
 (9)

其中，正类准确率（即印刷套不准图像识别准确率） $a^+ = T_p / (T_p + F_N)$ ，负类准确率（即印刷套准图像识别准确率） $a^- = T_N / (T_N + F_p)$ 。

表 1 混合矩阵
Tab.1 Confusion matrix

真实类别	预测类别	
	正类样本	负类样本
正类样本	正类样本被正确识别的数量 (T_p)	被错误识别为负类样本的正类样本数量 (F_N)
负类样本	被错误识别为正类样本的负类样本数量 (F_p)	负类样本被正确识别的数量 (T_N)

4.2 结果

实验提取 200 个印刷标志图像（包括 100 个印刷套准图像和 100 个印刷套不准图像），采用文献[3]中的方法提取图像的 8 维纹理特征 $T(1) \sim T(8)$ ，部分印刷标志图像的纹理特征数据参见文献[6]。在训练阶段，仅采用印刷套准图像的 8 维纹理特征对 SVDD 进行训练，获得 SVDD 模型，并使用网格寻优和 5 折交叉验证方法确定模型最优参数 C 和 σ 。SVDD 参数选择结果 3D 视图和等高线图分别见图 5 和图 6。在训练集上，当 $C=0.707\ 11$ 和 $\sigma=4$ 时，SVDD 模型取得 5 折交叉验证最大的平均预测准确率为 97.3646%，因此最优模型参数 (C, σ) 为 $(0.707\ 11, 4)$ 。

在测试阶段，利用获得的 SVDD 模型对测试数据进行识别分类，包含在超球体内的测试数据为印刷套准图像，在超球体外的测试数据为印刷套不准图像。为了和基于支持向量机的采样方法作比较，本实验采用文献[6]中的无采样方法^[20]（标记为 SVM）、单边欠采样方法^[21]（标记为 US）、SMOTE 过采样方法^[22]（标记为 SMOTE）、新的集成采样方法（New Integrated Sampling，标记为 NIS）^[6]分别对不平衡的印刷标志图像训练集进行采样预处理，并使用二分类模型 SVM 对印刷标志图像套准状态进行识别，结果见表 2。




图 5 SVDD 参数 C 和 σ 选择结果（3D 视图）
Fig. 5 Parameters C and σ determination in the SVDD model (3D view)




图 6 SVDD 参数 C 和 σ 选择结果（等高线）
Fig.6 Parameters C and σ determination in the SVDD model (contour map)

表 2 不同方法获得的印刷标志图像套准状态识别结果
Tab.2 Results of printing mark image registration by different methods

方法	a^+	a^-	a	G_{mean}
SVM	0.7813	1	0.8456	0.8839
US	0.8542	1	0.8971	0.9242
SMOTE	0.875	1	0.9118	0.9354
NIS	0.9375	0.95	0.9412	0.9437
文中方法	0.9538	0.9488	0.95	0.9513

4.3 分析与讨论

从表 2 可以看出，提出的 SVDD 方法对印刷套不准图像（即少类样本）识别准确率 a^+ 为 0.9538，明显高于 SVM，US 和 SMOTE 方法，略高于 NIS 方法（0.9538-0.9375=0.0163）；SVDD 方法对印刷套准图像（即多类样本）的识别准确率 a^- 为 0.9488，低于 SVM，US 和 SMOTE 方法，略低于 NIS 方法（0.9500-0.9488=0.0012），但 SVDD 方法对印刷标志图像的总识别准确率 a 为 0.9500，优于其他方法。

从对不均衡数据分类性能的角度评价,SVDD 方法获得的分类准确率的几何平均数 G_{mean} 为 0.9513, 优于其他方法。这表明仅由印刷套准图像训练获得的 SVDD 模型构建的超球体, 可以很好地将印刷套准图像包含在内, 而将印刷套不准图像排除在外。从实验结果看, 虽然牺牲了一些印刷套准图像的识别准确率, 可是显著提高了印刷套不准图像的识别准确率, 最终获得的识别准确率的几何平均数 G_{mean} 是最大的。虽然本方法在印刷套准图像识别上误判率略高, 但即使误判, 也不会造成不良的印刷品。印刷套不准图像的识别是印刷套准检测最关注的问题, 本方法显著提高了印刷套不准图像识别准确率, 这可以大大降低生产线上印刷品的不良率。

与文献[6]中提出的 NIS 方法相比, 提出的 SVDD 方法的印刷套不准图像分类准确率 a^+ 、总体分类准确率 a 和分类准确率几何平均数 G_{mean} 非常接近。NIS 方法是基于样本贡献差异, 分别对支持向量和非支持向量采用不同的采样策略, 提高训练集样本的均衡性, 然后采用二分类模型的支持向量机进行分类, 分类效果比 SVM, US 和 SMOTE 要好; 但与 SVDD 方法相比, NIS 方法对训练样本进行预处理, 势必会增加模型训练的时间; 同时如果少类样本的支持向量数量较少或者多类样本的非支持向量数量较少, 会严重影响 NIS 方法的预处理效果。提出的 SVDD 方法不需要对训练样本进行采样预处理操作, 节省了模型的训练时间, 同时也避免了 NIS 方法受支持向量和非支持向量数量的影响。

5 结语

针对不均衡的印刷标志图像训练集构建的二分类模型, 对少类的印刷套不准图像识别准确率低的问题, 提出采用支持向量数据描述方法, 仅对印刷套准图像进行训练, 构建单分类模型, 根据此模型来识别印刷标志套准状态。文中提出的方法获得的印刷标志套准识别总体准确率为 0.9500, 印刷标志图像套准识别准确率几何平均数 G_{mean} 为 0.9513, 优于实验中的 SVM 方法、US 方法、SMOTE 方法和 NIS 方法。

参考文献:

- [1] 陈汉文. 基于模式识别的彩色印刷品套准方法研究[D]. 南京: 南京理工大学, 2008.
CHEN Han-wen. Research on Color Printing Registration Method Based on Pattern Recognition[D]. Nanjing: Nanjing University of Science and Technology, 2008.
- [2] 简川霞, 高健, 李克天, 等. 基于机器视觉的印刷套准识别方法研究[J]. 电视技术, 2015, 16: 69—72.
JIAN Chuan-xia, GAO Jian, LI Ke-tian, et al. A Study

- on Printing Registration Recognition Based on Machine Vision[J]. Video Engineering, 2015, 39(7): 129—133.
- [3] 简川霞, 高健, 李克天, 等. 印刷套准识别方法研究[J]. 包装工程, 2015, 36(7): 129—133.
JIAN Chuan-xia, GAO Jian, LI Ke-tian, et al. Printing Registration Recognition [J]. Packaging Engineering, 2015, 36(7): 129—133.
- [4] 于丽杰, 李德胜. 彩色印刷套准识别方法研究[J]. 计算机工程与应用, 2011, 47(5): 163—165.
YU Li-jie, LI De-sheng. Study on Identifying Register State of Color Printing[J]. Computer Engineering and Applications, 2011, 47(5): 163—165.
- [5] 张锡福. 基于机器视觉的套印对准技术研究[D]. 济南: 山东师范大学, 2015.
ZHANG Xi-fu. Overprint Alignment Technology Research Based on Machine Vision[D]. Jinan: Shandong Normal University, 2015.
- [6] 简川霞, 高健. 面向不均衡训练集的印刷图像套准状态检测方法[J]. 包装工程, 2018, 39(11): 158—164.
JIAN Chuan-xia, GAO Jian. Registration Recognition Methods of the Printing Images Oriented to the Imbalanced Training Set[J]. Packaging Engineering, 2018, 39(11): 158—164.
- [7] 朱朔, 白瑞林, 刘秦川. 基于果蝇优化算法-小波支持向量数据描述的滚动轴承性能退化评估[J]. 中国机械工程, 2018, 29(5): 602—608.
ZHU Shuo, BAI Rui-lin, LIU Qin-chuan. Rolling Bearing Performance Degradation Assessment Based on FOA-WSVDD[J]. China Mechanical Engineering, 2018, 29(5): 602—608.
- [8] 王国柱, 刘建昌, 李元. 稀疏性 SVDD 方法在故障检测中的应用研究[J]. 东北大学学报(自然科学版), 2015, 36(6): 761—764.
WANG Guo-zhu, LIU Jian-chang, LI Yuan. An Applied Research of Sparsity SVDD Method to the Fault Detection[J]. Journal of Northeastern University (Natural Science), 2015, 36(6): 761—764.
- [9] YI-HUNG L, SZU-HSIEN L, YI-LING H, et al. Automatic Target Defect Identification for TFT-LCD Array Process Inspection Using Kernel FCM-Based Fuzzy SVDD Ensemble[J]. Expert Systems with Applications, 2009, 36(2): 1978—1998.
- [10] 杨娟, 黄心汉. 基于 SVDD 和多分辨率的铸坯表面缺陷检测[J]. 计算机与数字工程, 2012, 40(12): 139—141.
YANG Juan, HUANG Xin-han. Steel Surface Defect Detection Based on SVDD[J]. Computer & Digital Engineering, 2012, 40(12): 139—141.
- [11] 周崑. 电梯钢索纹理缺陷的 SVDD 检测方法[J]. 电脑编程技巧与维护, 2018(4): 18—20.
ZHOU Yin. SVDD Detection Method for Elevator Rope Defect[J]. Computer Programming Skills & Maintenance, 2018(4): 18—20.

- [12] KHAZAI S, SAFARI A, MOJARADI B, et al. Improving the SVDD Approach to Hyperspectral Image Classification[J]. IEEE Geoscience and Remote Sensing Letters, 2012, 9(4): 594—598.
- [13] 朱启兵, 冯朝丽, 黄敏, 等. 基于高光谱图像技术和SVDD的玉米种子识别[J]. 光谱学与光谱分析, 2013, 33(2): 517—21.
- ZHU Qi-bing, FENG Chao-li, HUANG Min, et al. Maize Seed Recognition Based on Hyperspectral Imaging Technology and SVDD[J]. Spectroscopy and Spectral Analysis, 2013, 33(2): 517—521.
- [14] TAX D M J, DUIN R P W. Support Vector Data Description[M]. Kluwer Academic Publishers, 2004.
- [15] SCHOLKOPF B, SMOLA A J. Learning with Kernels: Support Vector Machines, Regularization, Optimization, and Beyond [M]. Cambridge: MIT Press, 2001.
- [16] 刘艳红. SVDD算法研究及在信用卡欺诈检测中的应用[D]. 镇江: 江苏大学, 2010.
- LIU Yan-hong. Research on SVDD Algorithm and Its Application in Credit Card Fraud Detection[D]. Zhenjiang: Jiangsu University, 2010.
- [17] 范永东. 模型选择中的交叉验证方法综述[D]. 太原: 山西大学, 2013.
- FAN Yong-dong. A Summary of Cross-Validation in Model Selection[D]. Taiyuan: Shanxi University, 2013.
- [18] 万鹏. 基于流形学习的主轴系统故障诊断方法研究[D]. 北京: 北京信息科技大学, 2012.
- WAN Peng. Research on Fault Diagnosis of Spindle System Based on Manifold Learning[D]. Beijing: Beijing Information Science and Technology University, 2012.
- [19] CHAWLA N V. Data Mining for Imbalanced Datasets: An Overview[M]. Data Mining and Knowledge Discovery Handbook. Germany: Springer, 2005: 853—867.
- [20] VAPNIK V. The Nature of Statistical Learning Theory[M]. New York: Springer, 1995.
- [21] KUBAT M, MATWIN S. Addressing the Curse of Imbalanced Training Sets: One-Sided Selection[C]. The 14th International Conference on Machine Learning. Morgan Kaufmann, 1997: 179—186.
- [22] CHAWLA N V, BOWYER K W, HALL L O, et al. SMOTE: Synthetic Minority Over-Sampling Technique [J]. Journal of Artificial Intelligence Research, 2002, 16(1): 321—357.